

## تعیین کیفیت آب در طول مسیر رودخانه با استفاده از شبکه‌های عصبی مصنوعی تکاملی

### (مطالعه موردی رودخانه کارون بازه شهیدعباسپور - عرب اسد)

محمد نیکو<sup>1\*</sup>، مهدی نیکو<sup>1</sup>، یحیی بابایی نژاد<sup>2</sup>، آزاده امیری<sup>3</sup> و قدرت ام. رستم پور<sup>4</sup>

(۱) کارشناسی ارشد، گروه عمران آموزشکده فنی و حرفه‌ای سما، دانشگاه آزاد اسلامی واحد اهواز، ایران.

(۲) استادیار، گروه کشاورزی، دانشگاه آزاد اسلامی، واحد اهواز، اهواز، ایران.

(۳) استادیار، گروه جغرافیا، دانشگاه آزاد اسلامی، واحد اهواز، اهواز، ایران.

(۴) استادیار، گروه زمین شناسی، دانشگاه آزاد اسلامی، واحد اهواز، اهواز، ایران.

\* نویسنده مسئول مکاتبات: Sazeh84@yahoo.com

تاریخ پذیرش: ۹۰/۰۵/۲۳

تاریخ دریافت: ۹۰/۰۳/۲۱

### چکیده

رودخانه‌ها به عنوان اصلی ترین منبع تأمین کننده نیاز شرب، کشاورزی و صنعت از اهمیت خاصی برخوردار هستند. از طرفی کیفیت آب از لحاظ شرب نیز در بین پارامترهای کیفی مهم ترین متغیر می‌باشد. لذا بررسی و پیش‌بینی تغییرات پارامترهای کیفی در طول یک رودخانه، یکی از اهداف مدیران و برنامه ریزان منابع آب، می‌باشد. در این راستا تعداد زیادی مدل‌های کیفیت آب، در زمینه مدیریت بهتر برای حفظ کیفیت آب، گسترش یافته است. در این میان مدل‌های شبکه عصبی مصنوعی که با الهام از ساختار مغز بشر عمل می‌نمایند، به عنوان گزینه‌ای برتر، مورد تحقیق و بررسی قرار می‌گیرد. این تحقیق بر روی رودخانه کارون، بزرگترین رودخانه کشور و با استفاده از پارامترهای اندازه گیری شده در ایستگاه‌های موجود در طول رودخانه (بازه شهیدعباسپور - عرب اسد) انجام شده است. بدین منظور، دبی، ماه، طول رودخانه و پارامترهای الکترونیکی اندازه گیری شده در ایستگاه‌های شهیدعباسپور، پل شالو، گتوند و عرب اسد به عنوان ورودی‌های مدل، در نظر گرفته شد. با استفاده از مدل شبکه عصبی، نسبت جذب سدیم (SAR) و کل املاح محلول (TDS) اندازه گیری شده در همان ایستگاه‌ها نیز پیش‌بینی می‌گردد. از جمله مواردی که در این تحقیق به عنوان یک روش جدید استفاده شده است، تعیین شاخص‌های کیفی آب، در چند ایستگاه به صورت هم زمان می‌باشد. به منظور بهینه کردن هر کدام از مدل‌های شبکه عصبی مصنوعی، از الگوریتم ژنتیک استفاده گردید. نتایج نشان می‌دهد که مدل شبکه عصبی مصنوعی انتخاب شده، نسبت به مدل‌های آماری رگرسیون غیرخطی از توانایی، انعطاف پذیری و دقت بیشتری در پیش‌بینی کیفیت آب در رودخانه برخوردار می‌باشد.

واژه‌های کلیدی: شبکه عصبی مصنوعی، الگوریتم ژنتیک، طول مسیر رودخانه، کیفیت آب، رگرسیون غیرخطی.

## مقدمه

رودخانه‌ها به عنوان مهم‌ترین منبع تامین و انتقال آب مصرفی بخش‌های صنعت و کشاورزی، از اهمیت خاصی برخوردارند. توسعه روزافزون فعالیت‌های کشاورزی و صنعتی و نیز افزایش قابل توجه حجم فاضلاب‌های شهری، موجب آلودگی منابع آب، خصوصاً رودخانه‌ها گشته به نحوی که کیفیت این منبع حیاتی، را در بسیاری از نقاط مورد مخاطره جدی قرار داده و حتی که در برخی نقاط، منجر به مرگ بیولوژیکی رودخانه‌ها گردیده است. رودخانه دارای یک اکوسیستم پیچیده است، شامل: مواد معدنی (آلت، فسفر، آهن و ...)، تولیدکننده‌ها (نظیر جلبک‌ها)، مصرف کننده‌ها (نظیر پلانگتون‌ها) و تجزیه کننده‌ها (نظیر باکتری‌ها و قارچ‌ها). قدرت تصفیه طبیعی یک رودخانه، تابعی از شرایط هیدرولیکی و هیدرولوژیکی آن رودخانه بوده و بیانگر، توان حذف مواد آلاینده به وسیله آن می‌باشد. از آنجا که حفاظت کیفی آب رودخانه‌ها، نیاز به سرمایه‌گذاری‌های اضافی جهت تصفیه پساب‌ها یا سیستم‌های جمع آوری و کنترل زه آبها دارد و از طرفی نیز ممکن است، منجر به محدود کردن توسعه فعالیت‌ها در حوزه رودخانه گردد از این رو می‌تواند اثرات اقتصادی قابل توجهی داشته باشد. بنابراین وجود یک ابزار کامپیوتی به منظور پیش‌بینی و نشان دادن شرایط موجود و آتی و نیز محدودیت‌های لازم جهت دستیابی به استانداردهای کیفی، ضروری به نظر می‌رسد. رودخانه کارون به عنوان بزرگ‌ترین و پرآب ترین رودخانه کشور محسوب می‌شود. این رودخانه پس از ورود به دشت خوزستان، در معرض تحولات شدید فیزیکی، شیمیایی و بیولوژیکی قرار می‌گیرد. الحال رودخانه‌های شور واقع در این محدوده، به همراه فاضلاب صنایع و زه آب‌های کشاورزی و حوضچه‌های پرورش ماهی که بدون هیچ گونه تصفیه‌ای مستقیماً وارد رودخانه می‌شوند، وضعیت نامطلوبی را از نظر آلودگی کیفی آب رودخانه به وجود آورده و پیش‌بینی می‌شود با تخلیه فاضلاب‌های شهری و نیز بهره برداری از طرح‌های توسعه نیشکر و تخلیه آب‌های برگشتی این طرح‌ها به رودخانه مشکل کاهش کیفیت آب این رودخانه، در آینده جدی تر گردد. Faruk و همکاران در سال 2010 در مدل شبکه عصبی مصنوعی، به منظور پیش‌بینی کیفیت آب رودخانه به بررسی کاربرد مدل‌های ARIMA پرداختند. آنها در تحقیقشان به در رودخانه ماندرس کشور ترکیه پیش‌بینی DO و BOD پرداختند. ضریب  $R^2$  برای دو پارامتر یاد شده در آموزش، به ترتیب 0/902 و 0/893 شد که نشان دهنده آموزش مناسب شبکه می‌باشد.

و همکاران در سال 2008 از دانشگاه NUS سنگاپور، به بررسی کیفیت آب سواحل سنگاپور پرداختند. آنها از شوری آب، دما، اکسیژن و کلروفیل محلول در آب به عنوان پارامترهای ورودی استفاده کردند. مدل شبکه عصبی مصنوعی به دست آمده در این تحقیقات، دارای ضریب  $R^2$  برابر 0/8 و 0/9 در مراحل آموزش و آزمون بود که بیانگر آموزش مناسب این مدل، در تعیین کیفیت آب است.

Zhang در سال 1998 به پیش‌بینی پارامترهای کیفی آب رودخانه با استفاده از مدل شبکه عصبی مصنوعی پرداختند. آنها این بررسی را بر روی رودخانه ساسکاچون به مرحله‌ی اجرا درآوردند. Kuo و همکاران از دانشگاه NTU کشور تایوان در سال 2006 به بررسی ترکیب الگوریتم ژنتیک با شبکه‌های عصبی مصنوعی، جهت مدیریت کیفیت آب پرداختند. آنها از این مدل، به منظور پیش‌بینی غلظت فسفرکل، در مخزن سد فیتسسوی استفاده نموده و به منظور بهینه کردن شبکه عصبی مصنوعی، از الگوریتم ژنتیک، استفاده کرده‌اند. نتایج نشان می‌دهد که مدل بهینه شده با الگوریتم ژنتیک، در پیش‌بینی کیفیت مخزن سد، توانایی بالایی دارد. Singh و همکاران در سال 2009 به تعیین پارامترهای کیفی آب با استفاده از مدل شبکه عصبی مصنوعی پرداختند. این بررسی بر روی رودخانه گومتی در کشور هند انجام شد. آنها از یازده متغیر کیفی آب، به عنوان ورودی استفاده کرده و برای هر کدام از پارامترهای DO و BOD یک مدل شبکه

عصبی مصنوعی مجزا، تعیین نمودند. نتایج نشان داد که مدل شبکه عصبی مصنوعی، توانایی بالای در پیش بینی DO و BOD دارد.

yarmohammadi و همکاران در سال 2007 در یک مقاله، با استفاده از مدل شبکه عصبی، پارامترهای هدایت الکتریکی (EC)، نسبت جذب سدیم (SAR) و کل املح محلول (TDS) اندازه گیری شده در ایستگاه‌ها را، شبیه سازی کردند. آنها این بررسی را بر روی رودخانه کرخه انجام دادند. نتایج به دست آمده، توانایی بالای شبکه‌های عصبی مصنوعی را در شبیه سازی کیفیت آب رودخانه کرخه نشان داد.

Misaghy و همکاران در سال 2005 در مقاله‌ای به بررسی قابلیت شبکه‌های عصبی مصنوعی پرداختند. آنها از اطلاعات کیفی DO و BOD اندازه گیری شده در 14 ایستگاه موجود در طول رودخانه تا با تلاق گاوخونی استفاده کردند. در ادامه نتایج حاصل از مدل‌های شبکه عصبی مصنوعی را با مدل کیفی QUAL2E مقایسه کردند، که نشان دهنده توانایی مناسب شبکه‌های عصبی، در شبیه سازی تغییرات پارامترهای کیفی مذکور بود.

Yazdani و همکاران در سال 2008 در مقاله‌ای به بررسی قابلیت شبکه‌های عصبی مصنوعی پرداختند. در این تحقیق که بر روی رودخانه زاینده رود انجام شد. با استفاده از مدل شبکه‌های عصبی، چند پارامتر کیفی آب، در مقیاس ماهانه، مورد بررسی قرار گرفت. آنها با تغییر ورودی‌ها، نرخ یادگیری، میزان گشتاور و تعداد گره‌ها در لایه مخفی را، به عنوان مناسب‌ترین شبکه بر اساس میزان خطا، انتخاب کردند. نتایج بیانگر کارایی نسبتاً مناسب شبکه‌های عصبی، در بررسی و تخمین پارامترهای کیفی آب، در صورت آموزش مناسب می‌باشد.

Nushady و همکاران در سال 2008 نیز در مقاله‌ای، به بررسی قابلیت شبکه‌های عصبی مصنوعی پرداختند. آنها در این مقاله برخی از پارامترهای کیفیت آب، شامل کلسیم، منیزیم، سدیم، پتاسیم و سولفات در طول رودخانه زاینده رود (از ابتداء تا انتهای) را با سیستم شبکه‌های عصبی مصنوعی، مورد بررسی و شبیه سازی قرار داده و تغییرات کیفیت آب، در طول این رودخانه را بررسی نمودند.

تحقیق حاضر، بر روی رودخانه کارون انجام گرفته است. بدین منظور، پارامترهایی نظری: طول رودخانه، ماه، دبی و هدایت الکتریکی (EC) اندازه گیری شده در ایستگاه‌های شهید عباسپور، پل شالو، گتوند و عرب اسد، به عنوان ورودی‌های مدل شبکه عصبی بر گزیده شده و پارامترها یی نظری نسبت جذب سدیم و کل املح محلول در همان ایستگاه‌ها، به عنوان پارامتر خروجی انتخاب شده اند. مدل‌های شبکه عصبی مصنوعی استفاده شده، شامل: MLP، FF و RBF می‌باشد. هم چنین از الگوریتم ژنتیک، به منظور بهینه کردن مدل‌ها استفاده شده تا نتایج حاصل از پارامترهای TDS و SAR، به داده‌های واقعی، نزدیک تر گردد. در تحقیق از مدل رگرسیون غیرخطی، برای مقایسه با مدل شبکه عصبی مصنوعی استفاده شده است. مواردی که در تحقیق به عنوان یک روش جدید، استفاده شده، تعیین شاخص کیفی آب، در چند ایستگاه به طور همزمان در یک مدل پایدار می‌باشد. با استفاده از این مدل، در هر نقطه مورد نظر در طول مسیر رودخانه می‌توان پارامترهای TDS و SAR را تعیین نمود.

### معرفی شبکه عصبی مصنوعی و روش بهینه سازی الگوریتم ژنتیک

#### شبکه عصبی مصنوعی

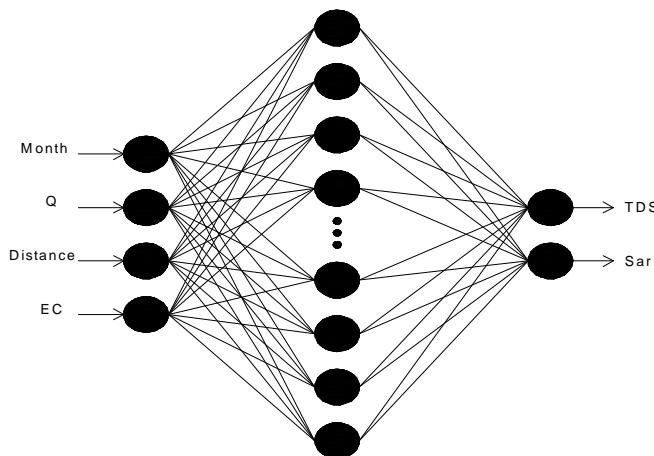
شبکه‌های عصبی مصنوعی، یکی از پویاترین حوزه‌های تحقیقاتی در دوران معاصر می‌باشد که توجه افراد بسیاری از رشته‌های گوناگون علمی را به خود جلب کرده است. فعالیت‌های تحقیقاتی اخیر در زمینه شبکه‌های عصبی، نشان داده که این روش، توانایی بسیار بالایی در

حل مسائل پیچیده در کلیه رشته‌های مهندسی را دارد. شبکه‌های عصبی هم چون مغز انسان، توانایی لازم را در یادگیری داشته و قادر به استفاده از تجارت به دست آمده در مسائل نو و مشابه می‌باشند. شبکه‌های عصبی مصنوعی با وجود اینکه با سیستم عصبی طبیعی قابل مقایسه نیستند، با این همه ویژگی‌هایی دارند که در بعضی از کاربردها، مانند: تفکیک الگو و یا هرجا که نیاز به یادگیری با یک نگاشت خطی و یا غیرخطی باشد، آنها را ممتاز می‌نمایند. از ویژگی‌ها و قابلیت‌های شبکه‌های عصبی مصنوعی می‌توان به مواردی هم چون: قابلیت یادگیری و تطبیق پذیری با اطلاعات موجود، قابلیت تعمیم دهنده، پردازش موازی و رودی‌های شبکه و در نتیجه افزایش سرعت پردازش، تحمل پذیری بالای خطاهای ... اشاره کرد. از اواخر دهه ۹۰، شبکه‌های عصبی مصنوعی در مسائل هیدرولوژی و ژئوهیدرولوژی مانند: مدل‌سازی بارش و رواناب، پیش‌بینی جریان رودخانه‌ها، مدل سازی آب‌های زیرزمینی، کیفیت آب، مدیریت آب، پیش‌بینی بارش و سری‌های زمانی و غیره استفاده می‌شوند. از میان کاربردهایی که برای شبکه‌های عصبی مصنوعی ذکر شد، پیش‌بینی کیفیت آب رودخانه، در مطالعات آب‌های سطحی، از اهمیت بالایی برخوردار است. شبکه‌های عصبی مصنوعی یک سیستم پردازشگر اطلاعات توده‌ای هستند که به صورت موازی قرار گرفته و عملکردی شبیه شبکه عصبی مغز انسان دارند. اصول زیر نشانگر اساس شبکه‌های عصبی مصنوعی می‌باشند:

۱. پردازش داده‌ها، در واحدهای منفردی به نام گره، صورت می‌گیرد. ۲. سیگنال‌های بین گره‌ها از طریق خطوط ارتباطی، انتقال می‌یابند.
۳. وزن نسبت داده شده به هر خط ارتباطی، نشانگر قدرت ارتباطی آن خط است. ۴. هر گره به طور معمول، دارای توابع فعال‌سازی و تبدیل گر، جهت تعیین سیگنال‌های خروجی، از داده‌های ورودی شبکه می‌باشد. ساختار شبکه‌های عصبی مصنوعی به وسیله الگوی ارتباط بین گره‌ها و متدها، تعیین وزن‌های ارتباطی و تابع فعالیت، معرفی می‌شود. ساختار عادی یک شبکه عصبی مصنوعی، معمولاً از لایه ورودی، لایه‌های میانی (پنهان) و لایه خروجی تشکیل شده است(شکل ۱). لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌ها است. آخرین لایه یا لایه خروجی شامل مقادیر پیش‌بینی شده به وسیله شبکه بوده و بنابراین خروجی مدل را معرفی می‌کند. لایه‌های میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها است. شمار لایه‌های مخفی و گره‌ها در هر لایه مخفی، به طور معمول به وسیله روش آزمون و خطا مشخص می‌شود. گره‌های لایه‌های مجاور در شبکه به طور کامل با هم در ارتباط هستند. ورودی‌های هر گره ممکن است از متغیرهای ورودی یا از خروجی گره‌های دیگر حاصل شود. هر گره دارای یک تابع تبدیل گر است. ورودی‌ها به شکل یک بردار ( $x_1, \dots, x_n$  و  $x_1, \dots, x_n$ ) بوده و هر ورودی توسط یک وزن، به گره پردازش گر مربوط می‌شود و در نهایت تسلسلی از وزن‌ها به شکل بردار وزن ( $w_1, \dots, w_n$  و  $w_1, \dots, w_n$ ) به گره مورد نظر مرتبط می‌گردد. وزن ارتباطی، از گره لایه پیشین به لایه مزبور را نشان می‌دهد. خروجی گره که لا نامیده می‌شود، طبق رابطه (۱) محاسبه می‌گردد:

$$y = f(x \cdot w - b) \quad (1)$$

در این رابطه،  $x$  داده‌های ورودی،  $w$  بردار وزن،  $b$  مقدار آستانه یا بایاس می‌باشند. درون هر گره، پردازش گر تابع تبدیل گر، تولید کننده خروجی‌های آن گره به شمار می‌رود.



شکل ۱: یک نمونه از شبکه عصبی مصنوعی با سه لایه

در ساختار شبکه‌های عصبی مصنوعی، از توابع تبدیل گر (تحریک) گوناگون، LinearAxon، BiasAxon، LinearSigmohidAxon، LinearTanhAxon، SigmohidAxon، TanhAxon می‌توان استفاده نمود. یکی از انواع مهم این توابع، تابع سیگموئید است:

$$f(t) = \frac{1}{1 + \exp(-tn)} \quad (2)$$

که در آن  $f(t)$  تابع تبدیل گر،  $n$  ورودی خالص نرون و  $t$  تقریبی است که بیانگر طول قسمت خطی نمودار تابع تبدیل گر می‌باشد، به طوری که اگر  $t$  بزرگ باشد، قسمت خطی تابع، به صورت عمودی درآمده و در واقع، تابع به شکل یک تابع حدی دو مقداره در می‌آید و اگر  $t$  کوچک باشد، تابع به شکل یک  $S$  کشیده در امتداد محور افقی در خواهد آمد. برای ارزیابی دقیق مدل شبکه عصبی مصنوعی معمولاً از دو معیار مختلف MSE (میانگین مربع خطاهای) و  $r^2$  استفاده می‌شود. MSE به صورت زیر محاسبه می‌شود:

$$MSE = \frac{\sum_{j=0}^P \sum_{i=0}^N (d_{ij} - y_{ij})^2}{N \times P} \quad (3)$$

MSE متوسط خطای مربعات نرمال شده است که به وسیله فرمول زیر بیان می‌شود:

$$NMSE = \frac{P \times N \times MSE}{\sum_{j=0}^P \frac{N \sum_{i=0}^N d_{ij}^2 - \left( \sum_{i=0}^N d_{ij} \right)^2}{N}} \quad (4)$$

$d_{ij}$  تعداد خروجی عناصر پردازش شده،  $N$  تعداد نمونه‌ها در مجموعه داده‌ها،  $y_{ij}$  خروجی شبکه برای نمونه  $i$  در عنصر پردازش شده  $j$  و  $P$  خروجی مورد نظر برای نمونه  $i$  در عنصر پردازش شده  $j$  می‌باشد. اختلاف مابین مقدار مشاهده شده و مقادیر محاسبه شده را

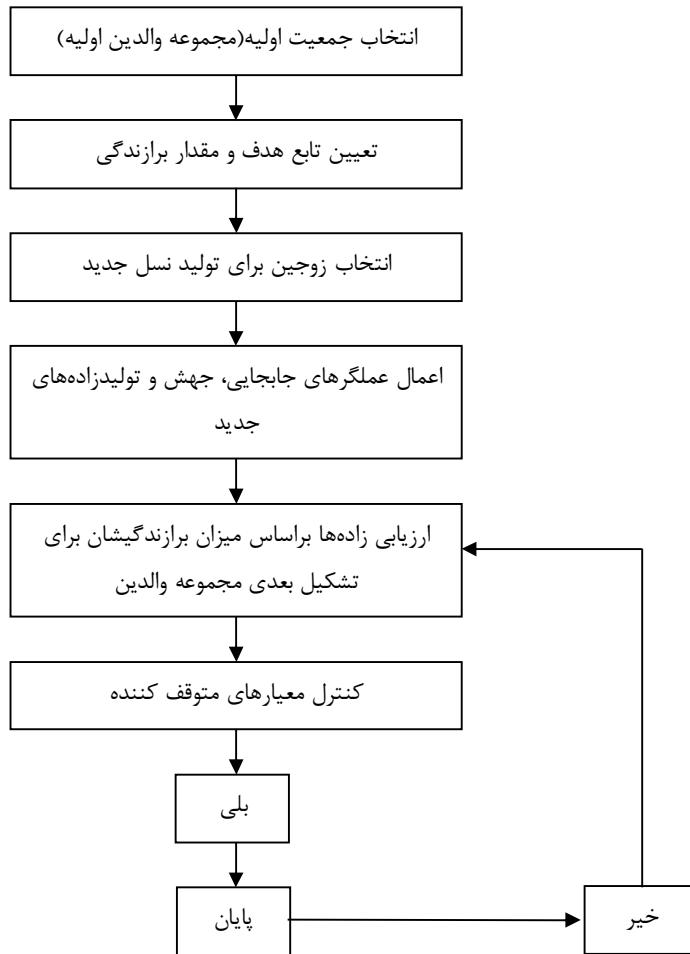
نشان می‌دهد. کمترین مقدار MSE، بالاترین صحت پیشگویی را بیان می‌کند. همچنین ۲ نشانگر میزان بازده شبکه بوده که به صورت زیر ارائه می‌گردد:

$$r = \frac{\sum_i (x_i - \bar{x})(d_i - \bar{d})}{\sqrt{\frac{\sum_i (d_i - \bar{d})^2}{N}} \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{N}}} \quad (5)$$

$\bar{x}$  خروجی شبکه،  $d_i$  خروجی مورد نظر،  $\bar{x}$  میانگین خروجی شبکه و  $\bar{d}$  میانگین خروجی مورد نظر می‌باشد. بهترین جواب برای مدل، هنگامی ایجاد خواهد شد که  $r$  به ترتیب به سوی یک و صفر میل کنند.

### روش بهینه سازی الگوریتم ژنتیک

الگوریتم ژنتیک، الهام گرفته از طبیعت بوده و تکامل طبیعت با فرضیه داروین، اساس شکل گیری آن می‌باشد که در آن بهترین‌ها حق با را دارند. الگوریتم ژنتیک توسط جان هلندر، متخصص علوم کامپیوتر دانشگاه میشیگان در سال ۱۹۶۲ ارایه شد. هلندر با ارائه رساله‌ی ای تحت عنوان "تطابق در طبیعت و سیستم‌های مصنوعی" به معرفی مفاهیم اصلی الگوریتم ژنتیک، شامل عملگرهای سه گانه: انتخاب (Selection)، آمیزش (Mutation) و جهش (Crossover) که در مورد سیستم‌های مصنوعی به کار می‌روند و هم چنین به مبانی ریاضی الگوریتم ژنتیک پرداخت. روش کار به این صورت است که، در فرآیند تکثیر، کروموزوم‌های با شایستگی بالا، شانس تکرار بیشتر، در جمعیت منتخب را پیدا می‌کنند و این کار توسط فرآیند انتخاب صورت می‌پذیرد. بدین منظور روش‌های متنوعی مطرح شده که روش چرخ گردان، معروف ترین آنها است. هم چنین از انتخاب، نخبه گرا نیز استفاده شده است. به این معنا که در هر نسل، تعدادی از بارزنه‌ترین افراد، بدون تغییر به نسل بعد منتقل می‌شوند. پس از تکمیل فرآیند انتخاب، نوبت به اعمال عملگیر بر روی جهت منتخب به منظور تولید جمعیت فرزندان می‌رسد. در انجام فرآیند پیوند، با انتخاب مقدار ثابت نرخ پیوند، به ترتیب برای هر کروموزوم یک عدد تصادفی تولید می‌شود. اگر عدد تصادفی تولید شده، از نرخ پیوند کمتر باشد، این کروموزوم انتخاب می‌شود تا با کروموزوم‌های بعدی که شرایط فوق را دارد، آمیزش نماید. در این روش از میان انواع مختلف پیوند، پیوند یکنواخت مورد استفاده قرار گرفته است. سپس نوبت به اعمال عملگر جهش می‌رسد. هدف از این کار ایجاد پراکندگی بیشتر در محدوده کاوش فضای طراحی است. در انجام فرآیند جهش، با انتخاب نرخ ثابت جهش، برای کلیه بیتها کروموزوم‌های جمعیت عدد تصادفی تولید می‌شود. اگر عدد تصادفی تولید شده، از نرخ جهش، کوچکتر باشد، مقدار آن بیت عوض می‌شود یعنی مقدار صفر به یک و بالعکس تبدیل می‌گردد. الگوریتم ژنتیک هنگامی که برخی ضوابط، مانند: تعداد معین تولید نسل و یا میانگین انحراف معیار عملکرد اشخاص جمعیت تامین شود، به پایان می‌رسد. در بهینه سازی کیفیت آب، معمولاً تابع هدف، پارامترهای کیفیت آب می‌باشند و به حداقل رساندن وزن، با برآورده کردن قیود مساله، هدف الگوریتم ژنتیک است. در شکل زیر فرآیند کلی حل مساله در الگوریتم ژنتیک، به طور خلاصه نشان داده شده است.



شکل 2: فرآیند حل مسائل بهینه سازی با استفاده از الگوریتم ژنتیک

## مواد و روش‌ها

### منطقه مورد مطالعه و جامعه آماری

رودخانه کارون به طول 890 کیلومتر از چهار شاخه اصلی: خرسان، آب ونک، آب کیار و بازفت تشکیل شده و از ارتفاعات مختلفی هم چون ارتفاعات شمالی اردکان فارس، جنوب و غرب بروجن سرچشمه می‌گیرد. منطقه مورد مطالعه رودخانه کارون، بازه شهیدعباسپور تا عرب اسد به طول 241 کیلومتری باشد. در این تحقیق، داده‌ها به صورت ماهانه از ایستگاه‌های هیدرومتری از تاریخ 1347 تا 1388 مورد استفاده قرار گرفته است که 80% داده‌های ورودی برای آموزش، 10% داده‌ها برای ارزیابی هم زمان با آموزش شبکه و 10% داده‌ها برای آزمون مدل‌های شبکه عصبی مصنوعی تکاملی در نظر گرفته شده است. در این تحقیق، پارامترهای طول رودخانه، ماه، دبی و هدایت الکتریکی (EC)، نسبت جذب سدیم (Sar) و کل املاح محلول (TDS) در چهار ایستگاه شهیدعباسپور، پل شالو، گتوند و عرب اسد اندازه گیری شده است به گونه‌ای که این پارامترها، در هر ماه یکبار اندازه گیری شده اند. این اندازه‌ها در جدول زیر آمده است:

جدول ۱: تعداد الگوهای مورد استفاده در طول مسیر رودخانه کارون

ردیف	رودخانه	ایستگاه	سال	فاصله از مبدأ	تعداد الگوهای	مورد استفاده
				(کیلومتر)		
1	شہید عباسپور		1347-1377	36,48	284	
2	پل شالو		1347-1383	130,85	337	
3	گتوند		1347-1388	164,31	470	
4	عرب اسد		1360-1388	241,01	313	
	جمع			1404	1404	

### روند انجام پژوهش

در شبکه عصبی مصنوعی، تعداد ورودی‌ها، چهار پارامترو تعداد خروجی‌ها ۲ پارامتر می‌باشند که در شکل (۱) نشان داده شده است. در این تحقیق، از سه مدل شبکه FF و RBF و MLP برای آموزش استفاده شده است. هم چنین برای بهینه کردن ساختار و تopolوژی هر شبکه، از الگوریتم ژنتیک استفاده گردید. از ۱۴۰۴ الگوی داده، ۸۰٪ الگوهای ۱۱۲۲ برای آموزش و ۱۰٪ الگوهای ۱۴۱ برای ارزیابی و ۱۰٪ انتخابی الگوها (۱۴۱ الگو) برای آزمون شبکه، مورد استفاده قرار گرفت. توابع تحریک مختلف شامل TanhAxon و Delta Bar Delta و Quickprop و Momentum و LinearAxon و SigmohidAxan و الگوریتم‌های آموزش مختلف، شامل: Gavin, 2004.

$$N_H \leq 2N_I + 1 \quad (6)$$

که در آن  $N_H$  تعداد گره‌های لایه‌های پنهان و  $N_I$  تعداد ورودی‌ها می‌باشد. با توجه به اینکه تعداد ورودی‌های موثر بدست آمده، برابر با ۴ عدد می‌باشد، حداقل تعداد گره‌های لایه پنهان، برابر با ۹ عدد می‌باشد ( $N_H \leq 9$ ). برای تعیین ساختار بهینه هریک از مدل‌های شبکه عصبی مصنوعی تکاملی، FF و RBF و MLP از نظر تعداد لایه‌های پنهان، تعداد گره‌ها در لایه‌های پنهان، الگوریتم یادگیری شبکه وتابع انتقال و قابلیت الگوریتم ژنتیک از نرم افزار NeuroSolutions استفاده شد. جدول زیر ساختار بهینه هریک از مدل‌ها و مشخصات مختلف آنها را که از الگوریتم ژنتیک به دست آمده را نشان می‌دهد.

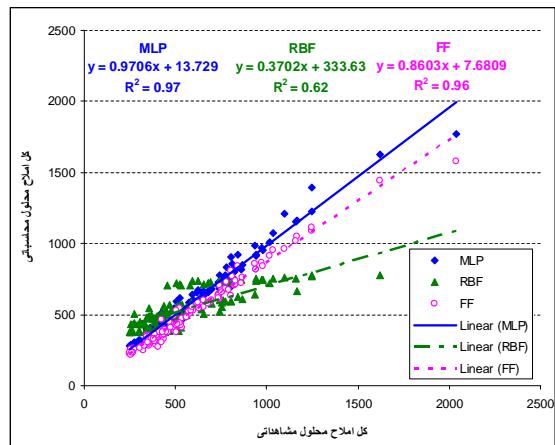
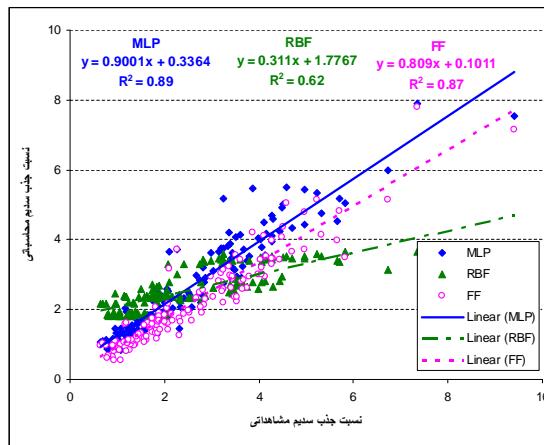
جدول 2: ساختار بهینه مدل‌های RBF و MLP و FF

ردیف	Threshold	Epoch	الگوریتم یادگیری شبکه	تابع انتقال	تعداد گره‌های لایه پنهان	تعداد خروجی‌ها ورودی‌ها	نام مدل
1			Delta Bar Delta	SigmoidAxon	9	FF	
2	0,001	3000	Momentum	TanhAxon	18	MLP	
3			QuickProp	SigmoidAxon	9	RBF	

هم چنین جدول 3 نتایج حاصل از آموزش، ارزیابی هم زمان با آموزش و آزمون هر یک از مدل‌های با ساختار بهینه که در جدول (2) آمده است را نشان می‌دهد. به منظور عملکرد مدل‌ها و تعیین بهترین مدل ، معیار NMSE و r حاصل از آزمون مدل‌ها با یکدیگر مقایسه می‌شود. همان طور که در جدول 3 ملاحظه می‌شود، مدل MLP دارای بیشترین همبستگی (r) برای داده‌های SAR و TDS در مرحله آزمون، نسبت به دو مدل دیگر می‌باشد. علاوه بر این مقادیر SAR و TDS محاسباتی، نسبت به مقادیر متناظر اندازه گیری شده در مرحله آزمون، به ازای مدل‌های مختلف در شکل‌های 3 و 4 نشان داده شده است.

جدول 3: نتایج حاصل از مدل‌های بهینه EANN

ردیف	آزمون								آموزش								اعتباریابی همزمان با آموزش								مدل							
	آزمون				آموزش				اعتباریابی همزمان با آموزش				آزمون				آموزش				آزمون				آموزش							
	نسبت جذب سدیم Sar		نسبت جذب سدیم TDS		نسبت جذب سدیم Sar		نسبت جذب سدیم TDS		نسبت جذب سدیم Sar		نسبت جذب سدیم TDS		نسبت جذب سدیم Sar		نسبت جذب سدیم TDS		نسبت جذب سدیم Sar		نسبت جذب سدیم TDS		نسبت جذب سدیم Sar		نسبت جذب سدیم TDS		نسبت جذب سدیم Sar							
	r	NMSE	r	NMSE	r	NMSE	r	NMSE	r	NMSE	r	NMSE	r	NMSE	r	NMSE	r	NMSE	r	NMSE	r	NMSE	r	NMSE	r	NMSE	r	NMSE				
FF	0.978	0/043	0/927	1/256	0/985	0/031	0/930	6/702	0/979	0/023	0/932	5/776	1																			
MLP	0.979	0/041	0/943	1/175	0/978	0/028	0/943	5/909	0/987	0/027	0/945	6/525	2																			
RBF	0/768	0/497	0/734	13/459	0/787	0/521	0/725	383/110	0/787	0/488	0/793	118/496	3																			



شکل 4: مقایسه مقادیر نسبت جذب سدیم مشاهداتی و محاسباتی توسط مدل‌های EANN در مرحله آزمون

شکل 3: مقایسه مقادیر کل املاح محلول مشاهداتی و محاسباتی توسط مدل‌های EANN در مرحله آزمون

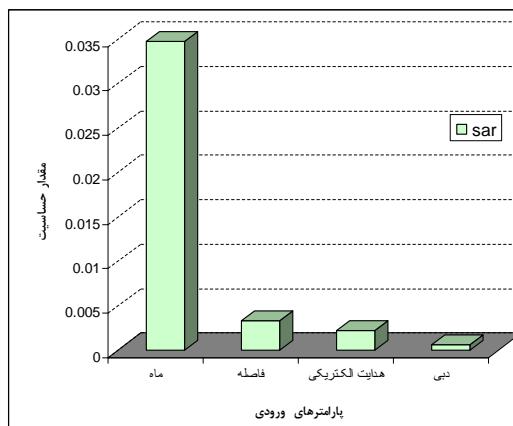
همان طور که در شکل‌های ۴ و ۳ مشاهده می‌شود در مدل  $MLP$  ضریب  $R^2$  برای پارامترهای  $TDS$  و  $SAR$  به ترتیب برابر ۰,۹۷ و ۰,۸۹ می‌باشد هم چنین شبی خط راست برای این دو پارامتر، برابر ۰,۹۷ و ۰,۹۰ می‌باشد. بنابراین مدل  $MLP$  همبستگی بالاتری نسبت به دو مدل دیگر دارد. هم چنین مدل  $FF$  همبستگی بالاتری نسبت به مدل  $RBF$  دارد. در نتیجه مدل  $MLP$  با ساختار آرایش (۴-۱۸-۲) بهترین مدل شبکه عصبی مصنوعی تکاملی می‌باشد.

#### آنالیز حساسیت خروجی‌های مدل بهینه $MLP$ نسبت به پارامترهای ورودی

برای آنکه میزان تاثیر پارامترهای ورودی بر روی پارامتر خروجی مشخص شود، از تکنیک آنالیز حساسیت استفاده می‌کنند. این تکنیک برای مشخص کردن این موضوع است که پارامتر خروجی در شبکه مورد نظر، نسبت به کدامیک از پارامترهای ورودی، دارای حساسیت بیشتری می‌باشد. تا مشخص شود که کدام یک، بر روی خروجی‌های شبکه عصبی مصنوعی بیشترین تاثیر را دارد. نتایج حاصل از آنالیز حساسیت خروجی مدل  $MLP$  نسبت به پارامترهای ورودی در جدول ۴ آمده نمودار هیستوگرام آن نیز در شکل‌های ۵ و ۶ آمده است.

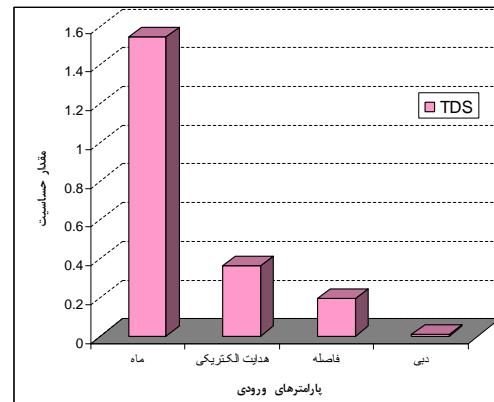
جدول ۴: آنالیز حساسیت خروجی مدل  $MLP$  نسبت به پارامترهای ورودی

نام پارامتر ورودی	نسبت جذب سدیم	کل املاح محلول
ماه	0/0347	1/544
هدایت الکتریکی	0/0022	0/363
فاصله	0/0033	0/191
دبی	0/0007	0/008



شکل ۶: آنالیز حساسیت پارامتر نسبت جذب سدیم در مدل  $MLP$

نسبت به پارامترهای ورودی



شکل ۵: آنالیز حساسیت پارامتر کل املاح محلول در مدل  $MLP$

نسبت به پارامترهای ورودی

با توجه به شکل‌های (5) و (6) پارامترهای ورودی ماههای سال و دبی رودخانه، به ترتیب، دارای بیشترین و کمترین تاثیر بر روی خروجی‌های SAR و TDS می‌باشند.

### مقایسه مدل شبکه عصبی مصنوعی با مدل‌های آماری

مدل آماری مورد استفاده در این تحقیق، مدل رگرسیون غیرخطی می‌باشد. در رگرسیون غیرخطی، دو یا چند متغیر مستقل، تاثیر عمده‌ای بر روی متغیر وابسته دارند که معادله آن به صورت زیر می‌باشد:

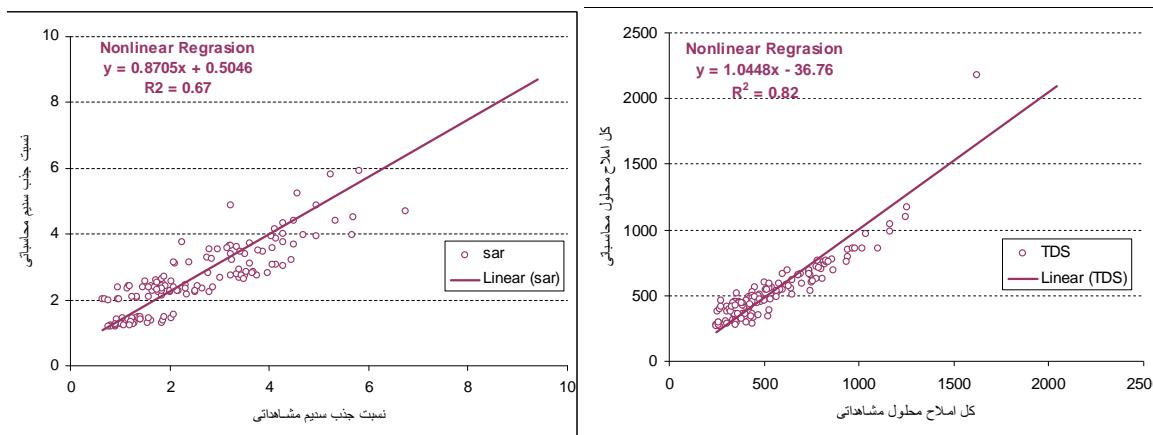
$$y = f(x_1, x_2, \dots) \rightarrow y = a_0 + a_1 x_1 + a_2 x_2 + \dots \quad (7)$$

در معادله فوق  $y$  متغیر وابسته،  $x_1, x_2, \dots, x_n$  متغیرهای مستقل،  $a_0, a_1, a_2, \dots, a_n$  ضرایب معادله از نوع رگرسیون می‌باشد. در این تحقیق برای متغیرهای ورودی و خروجی با استفاده از نرم افزار SPSS، مدل‌های مختلفی از رگرسیون خطی و غیرخطی مورد بررسی قرار گرفت. بهترین مدل رگرسیون غیرخطی که با داده‌های کل املاح محلول و نسبت جذب سدیم هماهنگی بیشتری داشت به صورت زیر به دست آمد.

$$y_1 = 0.005x_1 + 0.622x_2 + 0.752x_3 + 0.057x_4 - 11.006 \quad (8)$$

$$y_2 = 0.003x_2 - 0.020x_3 + 0.003x_4 - 0.278 \quad (9)$$

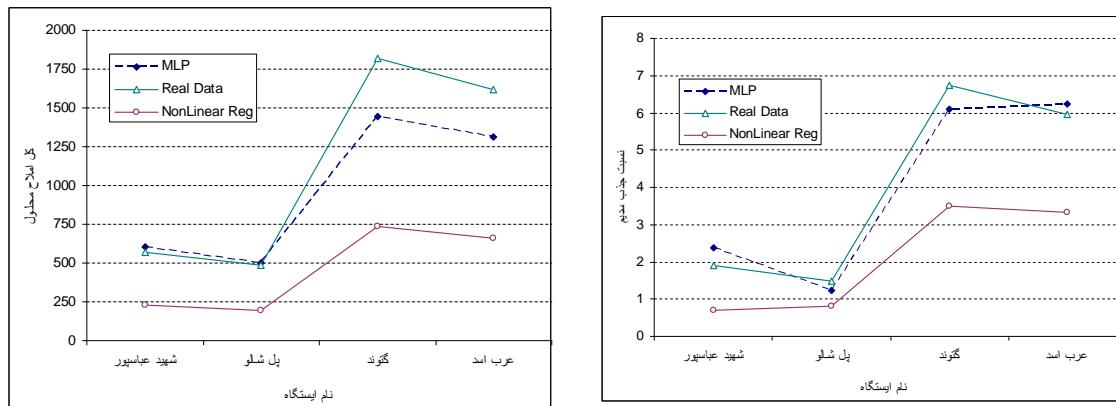
در معادله فوق  $y_1$  مقدار  $y_2$  مقدار SAR،  $x_1$  مقدار دبی رودخانه،  $x_2$  ماههای سال و  $x_3$  طول رودخانه کارون می‌باشد، ضریب  $R^2$  برای پارامترهای SAR و TDS به ترتیب برابر 0,67 و 0,82 می‌باشد. همچنین شیب خط راست برای این دو پارامتر به ترتیب، برابر 1,04 و 0,87 که برای این مدل رگرسیون غیرخطی مناسب می‌باشد. مقدار  $R^2$  و شیب خط راست برای معادله‌ها، به طور جداگانه در شکل‌های زیرنشان داده شده است.



شکل 8: مقایسه مقادیر محاسباتی توسط رگرسیون غیرخطی با مقادیر واقعی نسبت جذب سدیم

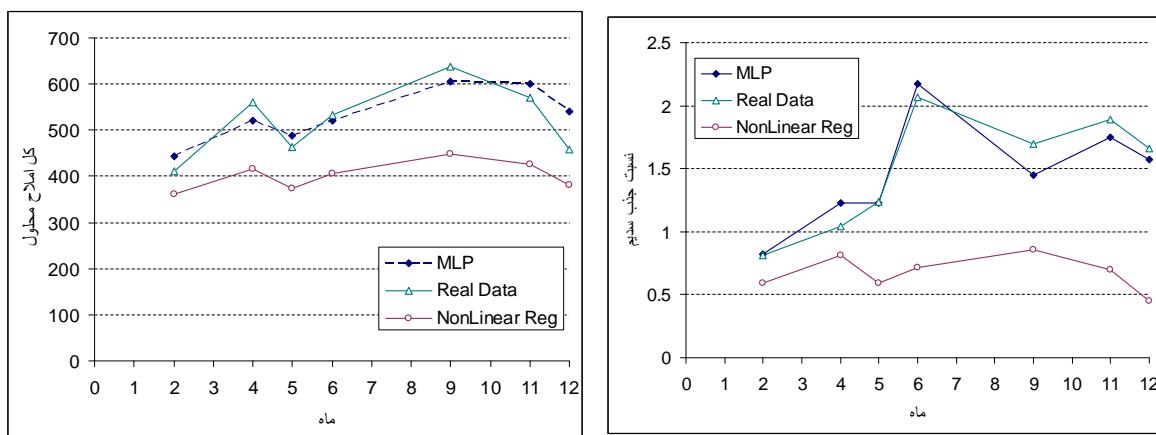
شکل 7: مقایسه مقادیر محاسباتی توسط رگرسیون غیرخطی با مقادیر واقعی کل املاح محلول

برای آنکه میزان دقیق و درستی خروجی حاصل از مدل‌های شبکه عصبی مصنوعی تکاملی، ارزیابی گردد از اطلاعات سال‌های ۱۳۷۷ در کل ایستگاه‌های به علت مشترک و موجود بودن در کل ایستگاه‌ها و سال ۱۳۸۲ در ایستگاه پل شالو و سال ۱۳۸۸ در ایستگاه‌های عرب اسد و گتوند استفاده شده است، از مهم ترین ویژگی این اطلاعات آن است که در هیچ کدام از مراحل آموزش، اعتباریابی و تست، مورد استفاده قرار نگرفته است. در شکل‌های ۹ و ۱۰ با توجه به تغییر طول مسیر رودخانه در اسفندماه، مقدار SAR و TDS در ایستگاه‌های مختلف پیش‌بینی می‌گردد، این پیش‌بینی توسط دو مدل MLP و رگرسیون غیرخطی صورت می‌گیرد.

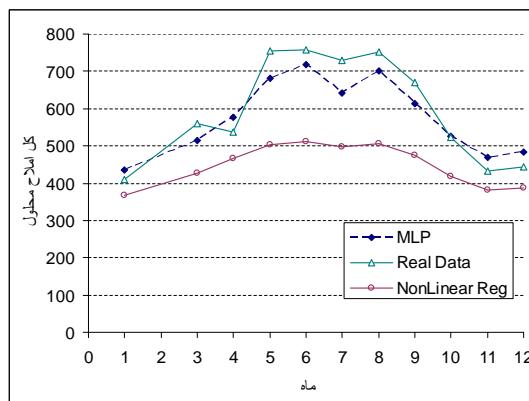


شکل ۹: نسبت جذب سدیم در طول مسیر رودخانه در سال ۱۳۷۷

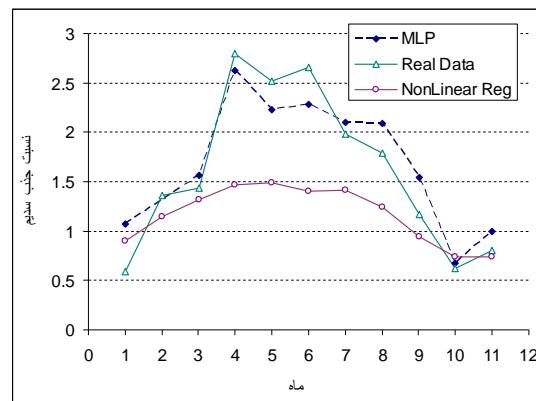
در شکل‌های (۱۱) و (۱۸) در هر ایستگاه به صورت مجزا در ماههای مختلف سال، مقدار SAR و TDS پیش‌بینی می‌گردد. این پیش‌بینی توسط دو مدل MLP و مدل رگرسیون غیرخطی صورت می‌پذیرد.



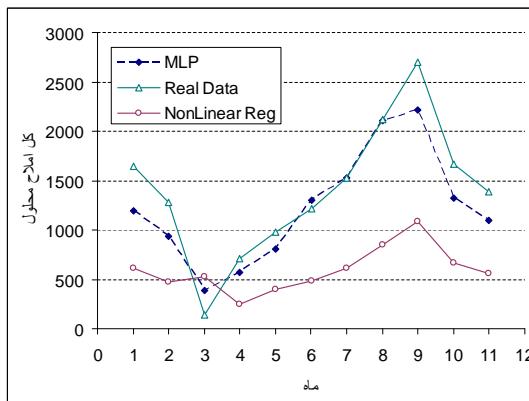
شکل ۱۰: نسبت جذب سدیم در ایستگاه شهید عباسپور سال ۱۳۷۷



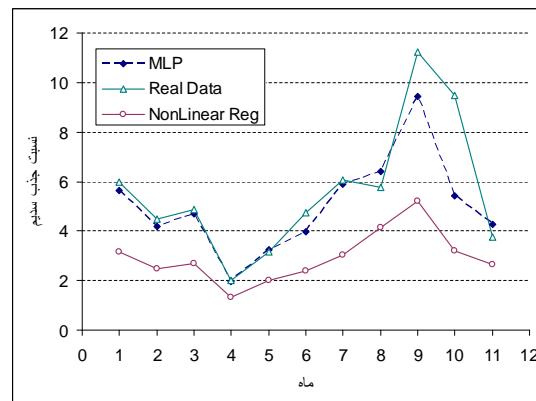
شکل 14: کل املاح محلول در ایستگاه پل شالو سال 1382



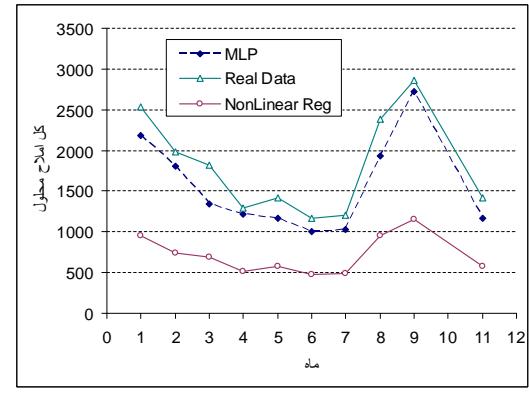
شکل 13: نسبت جذب سدیم در ایستگاه پل شالو سال 1382



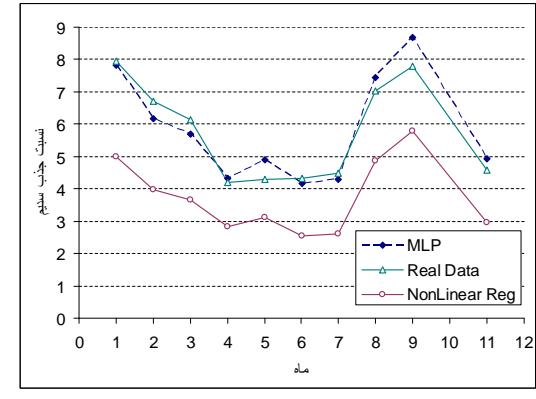
شکل 16: کل املاح محلول در ایستگاه گتوند سال 1388



شکل 15: نسبت جذب سدیم در ایستگاه گتوند سال 1388



شکل 18: کل املاح محلول در ایستگاه عرب اسد سال 1388



شکل 17: نسبت جذب سدیم در ایستگاه عرب اسد سال 1388

نتایج نشان می‌دهد، مدل MLP در طول مسیر رودخانه کارون در هر ایستگاه می‌تواند مقدار پارامترهای SAR و TDS را پیش بینی نماید (شکل‌های 9 و 10). علاوه بر این مدل MLP می‌تواند در هر ایستگاه، به طور جداگانه این پارامترها را در ماههای مختلف سال، پیش بینی نماید (شکل‌های 11 تا 18). با مقایسه مدل MLP با رگرسیون غیر خطی، می‌توان نتیجه گرفت که شبکه‌های عصبی مصنوعی، دارای دقت و انعطاف پذیری بالاتری نسبت به مدل‌های آماری می‌باشند.

### نتیجه‌گیری

مقایسه نتایج حاصل از آموزش، ارزیابی همزمان با آموزش و آزمون مدل‌های شبکه‌های عصبی مصنوعی، تکاملی با مقادیر آزمون اندازه‌گیری شده نشان می‌دهد که مدل‌های MLP، FF و RBF به ترتیب توانایی و دقت بیشتری در پیش‌بینی کیفیت آب رودخانه را دارند. با تاثیر پارامتر طول به عنوان داده‌های ورودی و با استفاده از مدل شبکه‌های عصبی مصنوعی حتی در مکان‌هایی که ایستگاه‌های اندازه‌گیری وجود نداشته باشد می‌توان پارامترهای کیفی آب را با توجه به حداقل اطلاعات تعیین نمود. مدل MLP انتخاب شده، توانایی قابل توجهی در پیش‌بینی هم زمان کیفیت آب رودخانه کارون در چند ایستگاه را دارد به گونه‌ای که در مقایسه با مدل رگرسیون غیرخطی، از دقت و انعطاف پذیری بالاتری برخوردار می‌باشد.

با قابلیت بهینه سازی الگوریتم پرکاربرد ژنتیک، می‌توان ساختار بهینه هریک از مدل‌های شبکه عصبی مصنوعی، از نظر تعداد لایه‌های پنهان، تعداد گره‌ها در لایه پنهان، نوع تابع تحریک و الگوریتم یادگیری شبکه مشخص نمود. به طوری که با این روش، زمان لازم برای تعیین ساختار بهینه هر مدل، به میزان قابل ملاحظه‌ای کاهش می‌یابد.

شبکه‌های عصبی مصنوعی تکاملی را ابزار مناسب و کارآمدی برای تعیین کیفیت آب رودخانه کارون هستند و با دقت قابل قبول و سرعت بالا می‌توانند پارامترهای کل املاح محلول و نسبت جذب سدیم را مشخص نموده و در تصمیم‌گیری‌های مربوطه موثر واقع شوند و جایگزین مناسبی برای بازرگانی‌های چشمی و روش‌های آماری شده و سبب صرفه جویی اقتصادی گردند.

### منابع

- **Faruk, D. O. (2010).** A hybrid neural network and ARIMA model for water quality time series prediction. *Engineering Applications of Artificial Intelligence*, pp. 23 (4).
- **Gavin J, G. C. (2004).** Input determination for neural network models in water resources applications. Part 1-background and methodology. *Journal Of Hydrology Elsevier*.
- **Kuo, j. T, Y.-Y. W.-S. (2006).** A hybrid neural–genetic algorithm for reservoir water quality management. *Water Research*, 40 (6).
- **Misaghly, K. M. (2005).** predictlioni of changes in river water quality using artificial neural networks. *Second National Student Conference on Water and Soil Resources* .
- **Nushady, M. A. (2008).** Simulation and prediction of calcium, magnesium, sodium, potassium, and sulfate in Zayandehrood river using artificial neural networks. *Fourth National Conference on Watershed Management Science and Engineering of watershed management*.
- **Paulo Chaves, T. K. (2007).** Deriving reservoir operational strategies considering water quantity and quality objectives by stochastic fuzzy neural networks. *Advances in Water Resources* , 30 (5) , PP.1329-1341.
- **Singh, A. B. Kunwar, P. (2009).** Artificial neural network modeling of the river water quality ,A case study. *Ecological Modelling*, 220 (6).
- **Yazdani, M. K. S. (2008).** Using artificial neural networks in assessing the quality status of rivers. *Fourth National Conference on Watershed Management Science and Engineering of watershed management*. *NeuroSolutions Getting Started Manual Version 4*. (2010). Retrieved from Neurosolutions Getting Started Manunal Version 4. (2010). Reterievh from Neurosolutions: www.nd.com.
- **Yarmohammadi, E. C.-m. ,.Z. (2007).** Using artificial neural networks in simulation Karkheh river water quality . *First Conference on Environmental Engineering* .
- **Zhang, Q.S.J, (1998).** Forecasting raw-water quality parameters for the North Saskatchewan River by neural network modeling. *Water Research* , 31 (9).